

面向大数据压缩存储桥梁损伤定位的 深度卷积自编码方法^{*}

钟紫婷 刘晨光 常军[†]

(苏州科技大学 土木工程学院, 苏州 215011)

摘要 为了解决桥梁健康监测数据体量大、存储难的问题,提出基于深度卷积自编码的数据压缩方法,并通过设计损伤指标,利用压缩数据识别结构损伤位置,保证数据压缩的有效性. 首先,设计合适的深度卷积自编码模型,以桥梁健康状态下的加速度自相关函数作为训练数据,得到合适的模型参数. 其次,将实时监测的加速度自相关函数输入训练好的深度卷积自编码模型,得到加速度自相关压缩数据. 然后,计算健康状态和实时状态下压缩数据的欧氏距离,作为损伤指标,每个损伤指标对应于相应的位置. 接着,根据指标是否变化判断相应位置的损伤状况. 最后,采用简支梁和连续梁的数值模型及简支梁试验模型对该方法进行了有效性和抗噪性的验证. 采用的损伤指标可通过压缩数据识别结构损伤位置,具有一定抗噪性,简支梁 20% 噪声、连续梁在 10% 高斯白噪声下可识别损伤位置.

关键词 桥梁健康监测, 损伤定位, 大数据压缩存储, 深度卷积自编码, 欧氏距离

中图分类号: U441

文献标志码: A

A Deep Convolutional Autoencoder Method For Bridge Damage Localization for Big Data Compression Storage^{*}

Zhong Ziting Liu Chenguang Chang Jun[†]

(School of Civil Engineering, Suzhou University of Science and Technology, Suzhou 215011, China)

Abstract To solve the problem of large volume and storage difficulty of bridge health monitoring data, the deep convolutional autoencoder is proposed to compress data. By designing a damage indicator, structural damage location is identified from the compressed data, thereby ensuring the effectiveness of the data compression. Firstly, an appropriate deep convolutional autoencoder model is designed, and the autocorrelation functions of acceleration responses under the healthy state of the bridge are used as training data to obtain appropriate model parameters. Secondly, the real-time monitored acceleration autocorrelation functions are input into the trained deep convolutional autoencoder model to obtain compressed data. Then, the Euclidean distance between the compressed data under both healthy and real-time states is calculated as a damage indicator, with each damage indicator corresponding to a specific structural location. Next, the damage condition at the corresponding location is determined according to whether the indicator changes. Finally, numerical models of a simply supported beam and a continuous beam, as well as a simply supported beam test in laboratory, are adopted to verify the effectiveness and noise robustness of the proposed method. Damage indicators can identify the location of structural damage through compressed data, with a certain level of noise resistance. The damage location of simply supported beams can be identified under 20% noise, and for continuous beams under 10% noise.

2025-03-19 收到第 1 稿, 2025-04-12 收到修改稿.

^{*} 国家自然科学基金项目(52208189), 江苏省研究生科研创新计划项目(KYCX23_3338), 江苏省高等学校基础科学(自然科学)面上项目(21KJB580006), National Natural Science Foundation of China (52208189), Jiangsu Graduate Research and Innovation Program(KYCX23_3338), Basic Science (Natural Science) of Jiangsu Provincial Colleges and Universities(21KJB580006).

[†] 通信作者 E-mail: Changjun21@126.com

Key words bridge health monitoring, damage localization, big data compression storage, deep convolution autoencoder, Euclidean distance

引言

近年来,结构健康监测技术(structural health monitoring, SHM)被广泛用于桥梁运营维护管理中,通过实时监测、数据分析、损伤识别和状态评价等环节,为桥梁的安全运营提供了有效的保证^[1-3]。目前,我国已在许多桥梁上安装健康监测系统,日积月累,这些健康监测系统采集海量监测数据^[4-7],给数据传输、存储及分析带来巨大难题。

数据压缩是减少数据存储成本的主要方法。压缩感知定理(compressed sensing, CS)是近年来解决 SHM 数据存储问题的主要方法之一^[8-10]。国内外学者通过对重构算法及观测矩阵进行改进,提高数据压缩效率。吴贤国等^[11]在隧道 SHM 系统中使用 CS 压缩数据,在保持较高的恢复率前提下,可同时利用多传感器对数据压缩,提高监测数据存储及传输效率。张笑华等^[12]通过优化 CS 中的观测矩阵,增加观测矩阵和稀疏基的不相关性,提高信号压缩感知的重构精度。Bao 等^[13]将机器学习与压缩感知相结合,利用深度神经网络(deep neural networks, DNNs)学习复杂基矩阵与压缩感知采样信号之间的映射关系,将求解过程化为一个对时间序列信号重构的有监督学习任务,提高数据的存储效率。

以上研究主要集中于数据的压缩及恢复精度的提高,未验证压缩效果。Almasri 等^[14]用离散余弦变换法对振动数据压缩,利用时频盲源分离法从重构数据中识别结构模态参数,成功验证压缩数据包含原始数据的重要特征。Kullaa^[15]将经验贝叶斯虚拟传感器引入数据压缩存储中,采用极值统计控制图对压缩重构数据进行损伤监测。虽然基于 CS 的数据压缩方法压缩效果好,恢复精度高,但其以下缺点限制了在桥梁 SHM 中的应用:求解通常基于某种基函数,是基于迭代的求逆问题;数据必须具有稀疏性;强噪声下数据压缩效果差。

深度学习是近年来人工智能领域的重要研究方向,它能够从海量数据中提取复杂特征,学习输入与输出间线性、非线性关系,对数据限制少,在桥梁 SHM 中得到广泛应用^[16,17]。其中,自编码器(auto-encoder, AE)是深度学习领域应用较广泛的网络模型之一。倪富陶^[18]借鉴传统的基于字典

的数据压缩方法,将深度学习网络从高维输入中学习到的特征看作是数据在某个空间上的变换,实现正常数据的压缩存储。

此外,自编码器也用于结构损伤识别领域。国内外学者^[19-21]以重构误差为损伤指标,实现损伤、损伤时刻的发现,但无法进行损伤定位;王宇鑫^[22]采用大小数据窗口嵌套策略,利用三层稀疏自编码的输出特征对简支梁模型进行损伤定位,然而该方法对小损伤识别效果较差,对损伤位置较敏感。以上损伤识别均利用了重构误差,对损伤定位的研究还不成熟。

目前,大数据压缩存储方面,深度学习方法应用较少,现有方法需要对压缩数据进行重构进而验证压缩数据的有效性,过程烦琐。为此,论文提出一种基于深度卷积自编码模型的数据压缩方法,并研究了直接从压缩数据中识别结构损伤位置,保证压缩数据的有效性。该方法有效解决数据存储问题,且不需要恢复原始数据,无需利用重构误差,可直接利用压缩存储数据进行损伤定位。所提方法适用于各类桥型。

1 深度卷积自编码模型

自编码模型由全连接神经元组成,编码器将输入数据 x 映射到任意低维空间 h ,解码器将 h 重构为输出 y 。因此, h 能以较少的特征表达输入的关键信息。各模块的传递函数如公式(1)、(2)所示:

$$h = f(x) = \phi(Wx + b) \quad (1)$$

$$y = g(h) = \phi'(W'h + b') \quad (2)$$

式中, x 、 y 分别为自编码的输入、输出数据, h 为隐藏层特征, W 、 W' 为编码器和解码器模块的权重矩阵, b 、 b' 为编码器和解码器模块的偏置向量, ϕ 、 ϕ' 为编码器和解码器模块的激活函数。

损失函数如公式(3)、(4)所示:

$$J = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x_i - y_i\|^2 \right) + \Omega(\theta) \quad (3)$$

$$[W_1, b_1, W'_1, b'_1] = \operatorname{argmin} J(\theta; y, x) \quad (4)$$

式中, θ 为训练获得的模型参数,包括权重矩阵 W_1 、 W'_1 与偏置向量 b_1 、 b'_1 ;下标 1 为第 1 隐层, $\Omega(\theta)$ 为施加在指定层权重矩阵上的正则项, N 为输入数据的个数。

卷积自编码模型(convolutional autoencoder, CAE)用卷积层代替 AE 中的全连接层,通过共享权重和偏置,减少参数量,更好保留特征信息.桥梁数据复杂,浅层网络结构容易损失有效信息,使用深度自编码模型,其多个隐藏层的分层非线性映射可有效提取特征.

本文采用的深度卷积自编码模型如图 1 所示,该模型包括编码器模块、解码器模块、展平层、瓶颈层及重塑层.1 个编码器模块包含 1 个卷积层、1 个池化层和 1 个激活函数,1 个解码器模块包括 1 个转置卷积层和 1 个激活函数.

池化层压缩特征,提取主要信息.选取最大池化法,以 2 个相邻数据中的最大值作为输出.

非线性激活函数可剔除冗余信息,增强网络非线性拟合能力.本文采用的激活函数是 Tanh,其能够将输出限定在 $[-1,1]$ 范围内,如公式(5)所示:

$$\text{Tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

式中, x 为神经元的输出值.

展平层将编码部分最后一个池化层的二维输出展开为一维,映射到瓶颈层,瓶颈层在整个模型中有最少的神经元,包含输入信息中的重要特征;重塑层将瓶颈层中的数据转化为符合解码器输入的二维数据.

在 Matlab 建立如图 1 所示深度卷积自编码模型,梯度下降算法采用 Adam (adaptive moment estimation),代价函数为均方根误差(RMSE),初始学习率为 $1e-3$,激活函数为 Tanh 函数,批量大小(batch size)为 16,训练轮次(epoch)为 50.输入输出维度为 2048×1 ,设置 3×1 的卷积核,各卷积层的填充(Padding)均设置为 same.




图 1 深度卷积自编码模型示意图

Fig. 1 Schematic diagram of deep convolution autoencoder

2 方法

2.1 去噪处理

自相关函数是描述某个随机信号在不同时刻

间的相关程度,可以用来寻找信号中的重复模式,具有一定的抗噪性.与加速度相比波形简单,其通过滑动求和使振动模态对应的周期信号更为明显,进一步提高自编码模型的重构精度.自相关函数计算如公式(6)所示:

$$R_{xx}(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} x(t)x(t+\tau) \quad (6)$$

式中, x 表示加速度响应, τ 表示时间延迟, N 表示总时间.

归一化可加快梯度下降的求解速度,提升模型的收敛速度,最大最小归一化方法如公式(7)所示:

$$\tilde{x} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (7)$$

式中, $\tilde{x}$ 为归一化后的数据, x 为自相关函数, $\max(x)$ 、 $\min(x)$ 分别为该段数据的最大、最小值.

2.2 特征提取

加速度自相关函数经过编码部分将关键特征映射到瓶颈层,解码部分通过反卷积、反池化作用将压缩特征尽可能恢复为原始数据.自编码实现数据压缩的同时保留原始信息的关键特征.因此,选择瓶颈层的压缩数据作为特征.

2.3 损伤指标

提取实时状态及健康状态下深度卷积自编码模型的瓶颈层压缩特征,以两种状态下压缩特征的欧氏距离作为损伤指标,如公式(8)所示:

$$DI = \sqrt{\sum_{i=1}^n (h_{H1}^i - h_{D1}^i)^2} \quad (8)$$

式中, DI 为损伤指标, h_{H1}^i 、 h_{D1}^i 分别为健康状态、实时状态下瓶颈层第 i 个特征, n 为瓶颈层的特征数.

连续梁支座处的特征不平稳,导致支座附近多项指标不平稳.以两组健康状态下压缩数据的欧式距离作为基准,计算实时状态与健康状态瓶颈层间的欧式距离到基准的偏差,如公式(9)所示:

$$DI = \frac{\sqrt{\sum_{i=1}^n (h_{H1}^i - h_{H2}^i)^2} - \sqrt{\sum_{i=1}^n (h_{D1}^i - h_{H1}^i)^2}}{\sqrt{\sum_{i=1}^n (h_{H1}^i - h_{H2}^i)^2}} \quad (9)$$

式中, h_{H1}^i 、 h_{H2}^i 为健康状态下的瓶颈层特征, h_{D1}^i 为实时状态下瓶颈层特征.

3 损伤定位操作步骤

基于深度卷积自编码模型的桥梁损伤定位方

法主要有 3 个步骤:数据预处理、模型建立和训练、损伤定位.

步骤 1: 数据预处理.

通过具有固定长度的时间窗沿加速度时间序列滑动得到加速度帧. 滑动窗口长度、步长均设置为 1024. 分别用公式(6)、(7)进行自相关及归一化计算.

步骤 2: 模型建立和训练.

将预处理后的健康状态数据按 8 : 2 划分为训练集和测试集. 搭建第 1 节中的深度卷积自编码模型, 训练集数据既是模型的输入又是模型的输出, 用训练集训练模型, 测试集评估模型. 每个深度卷积自编码模型对应于相应的传感器位置.

步骤 3: 损伤定位.

将实时状态和健康状态的数据输入训练好的深度卷积自编码模型中, 提取相应瓶颈层的加速度自相关压缩数据, 按式(8)或式(9)计算损伤指标, 每个损伤指标对应于相应位置, 损伤位置处的损伤指标远大于周围位置处, 通过指标变化实现损伤定位.

4 数值算例

4.1 简支梁算例模型

采用 Abaqus 建立 8 m 长的混凝土简支梁模型, 截面尺寸 0.15 m×0.2 m, 材料密度 2500 kg/m³, 弹性模量 30 GPa, 共划分 10 个单元, 见图 2, ①~⑩表示单元号, 1~9 为节点号. 共设置 4 种损伤工况, 见表 1. 通过改变损伤单元的弹性模量模拟损伤.

在 9 个节点施加白噪声激励, 白噪声激励服从 (0,10) 分布, 激励频率为 200 Hz. 在健康状态下, 施加白噪声激励 1000 s, 得到 200 000 个数据. 各工况下施加白噪声激励 400 s, 每个节点处得到 80 000 个数据.

建立 9 个深度卷积自编码模型, 将各工况数据输入训练好的模型, 提取瓶颈层的压缩特征. 训练的模型损失曲线见图 3. 模型最终收敛于 0.4, 训练良好.




图 2 简支梁示意图
Fig. 2 Schematic diagram of simply supported beam

表 1 简支梁损伤工况
Table 1 Damage cases of simply supported beam

Conditions	Injury unit	Extent of injury
D1	7	5%
D2	7	10%
D3	4、7	10%、20%
D4	3、7	20%、20%





图 3 损失曲线图
Fig. 3 Loss curve plot

因为传感器采集的是简支梁每个单元两端的数据, 所以当两个连续传感器处的损伤指标均大于周围的指标时, 该位置发生损伤, 按式(8)计算损伤指标.

损伤识别情况见图 4. D1、D2 工况下, 传感器 6、7 损伤指标明显大于周边指标, 即⑦单元发生损伤, 且 D2 工况损伤指标整体高于 D1 工况损伤指标, D2 的损伤程度相对较大, 如图 4(a)、(b)所示; D3 工况下, 传感器 3、4 的损伤指标低于传感器 6、7 的损伤指标但高于其他传感器, 即④单元与⑦单元发生损伤, 且⑦单元损伤程度相对更大, 如图 4(c)所示; D4 工况下, 传感器 2、3 和传感器 6、7 处的指标相近且大于其他传感器, 即单元③和单元⑦处发生损伤且损伤程度相近, 如图 4(d)所示.






图4 简支梁损伤定位图
Fig. 4 Damage location of simply supported beam

为了验证所提方法的抗噪性,向数值模拟加速度信号中添加高斯白噪声模拟环境的干扰,添加噪声方法见式(10):

$$\boldsymbol{x}_j^n = \boldsymbol{x}_j + \boldsymbol{x}_{j\max} \times \omega \times \alpha \tag{10}$$

式中, $\boldsymbol{x}_j^n$ 、 $\boldsymbol{x}_j$ 分别为测点 j 加入噪声前后的加速度信号, $\boldsymbol{x}_{j\max}$ 为该测点加速度的最大值, ω 是均值为 0、标准差为 1 的高斯白噪声, α 为加速度信号中加入的噪声程度。

在加速度信号中施加噪声,噪声程度低于 20% 时,所有工况都能够识别损伤. 以工况 D4 为例,施加 20%、25% 噪声后的损伤定位结果见图 5. 在 20% 噪声下,虽然正常位置处损伤指标增大,但与损伤位置




图5 噪声影响下简支梁损伤定位图
Fig. 5 Damage location of simply supported beam under noise impact

处差距较大,仍能识别损伤. 在 25% 噪声下,各损伤指标间差距不断减小,不能识别损伤. 因此,该方法在识别简支梁的损伤位置时抗噪性较好。

4.2 连续梁算例模型

采用 Abaqus 建立一个 26 m 长的三跨连续梁模型,划分 26 个单元,见图 6. 梁截面为 0.15 m×0.2 m,材料密度为 2500 kg/m³,弹性模量 30 GPa,在每个单元节点处施加服从(0,10)分布的白激励噪声,激励频率为 200 Hz. 无损状态下,施加一组 2000 s 的白噪声激励,每个节点共得到 400 000 个数据点;各工况下施加 500 s 白噪声激励,产生 100 000 点数据. 传感器位于每个单元中点,提取每个单元中点处的加速度数据. 连续梁共设置 3 种损伤工况,见表 2.

表2 连续梁梁损伤工况
Table 2 Damage cases of continuous beam

Conditions	Injury unit	Extent of injury
D1	13	10%
D2	13、16	10%
D3	4、13	10%




图 6 连续梁示意图
Fig. 6 Schematic diagram of continuous beam

连续梁的数据预处理过程及模型构架与简支梁相同,训练对应模型.提取瓶颈层的损伤特征,按式(9)、(10)计算损伤指标并进行加噪处理.

D3 工况损伤识别结果见图 7. 在 10% 噪声下,损伤位置处的指标变化较小,且远大于其他位置处指标,能识别损伤位置. 在 15% 噪声下,靠近支座处的指标不断增大,损伤位置与周围位置指标差距较小,出现个别伪损伤,不能识别损伤位置. 因此,该方法能对连续梁损伤定位,具有一定抗噪性.






图 7 连续梁损伤定位图
Fig. 7 Damage location of continuous beam

5 试验验证

为了进一步验证该方法的有效性,在实验室建立有机玻璃简支梁模型,尺寸(长×宽×高)为 1500 mm×200 mm×19 mm,共划分 10 个单元.在底部均匀布置 9 个测点,测点编号为 1~9,示意图如图 8 所示,①~⑩代表单元号,1~9 代表测点编号.试验根据单元等效刚度来计算简支梁的损伤程度,通过在 5 号单元和 8 号单元各自横向切割长度 $b=150\text{ mm}$,深度为 $2d$ 的切口来模拟损伤位置和损伤程度,单个单元的损伤程度为 $2d/L$.






图 8 简支梁试验示意图
Fig. 8 Schematic diagram of simply supported beam test

激振系统由世数 YE1311 信号发生器、YE5873A 功率放大器及激振器组成;位移传感器为 LVDT 高精度电感式直线位移传感器,最大量程为 30 mm;动态信号采集仪为东华测试 DH3822 便携式动态信号测试系统,采样频率最高为 1000 Hz.对简支梁跨中进行简谐强迫振动,激振频率 13 Hz,采集健康状态和损伤状态下的位移响应.位移响应的采样频率为 200 Hz.试验现场如图 9 所示.设置 ⑤单元损伤 30%,⑧单元损伤 20%,损伤识别结果如图 10 所示,成功识别损伤位置.



(a) 无损伤状态



(b) 损伤状态



(c) 动态信号采集仪

图 9 试验现场照片

Fig. 9 Photographs of the test site




图 10 试验识别结果

Fig. 10 Damage identification of the test

将深度卷积自编码模型与压缩感知理论分为记为 Model1、Model2,分析在不同压缩率下的数据重构精度(均方误差,MSE),对比结果见表 3,压缩感知理论计算时间较短,但每次数据压缩都需要重新计算,且在计算过程中占用更多内存.深度卷积自编码模型虽然训练时间略长,但同一桥梁只需训练一次即可,总体来说更加便捷高效,其重构数据精度较高.

此外,该模型适用于不同桥梁类型、不同荷载工况.但对于不同的桥梁,需要利用桥梁的健康响应进行重新训练.

表 3 不同模型重构结果对比

Table 3 Comparison of reconstruction results of different models

Compressibility	Model	MSE	Time
0.80	Model1	0.0221	7'13"
	Model2	0.0601	1'49"
0.65	Model1	0.0206	4'59"
	Model2	0.0612	1'26"
0.50	Model1	0.0175	4'27"
	Model2	0.0678	1'03"
0.25	Model1	0.0159	4'03"
	Model2	0.0904	0'46"

6 结论

针对桥梁 SHM 数据存储难的问题,将深度学习方法引入数据压缩,提出采用深度卷积自编码模型压缩数据,并直接利用压缩数据中的关键特征识别桥梁损伤位置,验证压缩的有效性.以健康状态下加速度自相关函数训练模型,每个模型对应于相应位置,计算损伤指标定位损伤.通过数值模拟和实验室试验验证该方法的有效性,并得到如下结论:

- (1)采用深度卷积自编码模型对桥梁 SHM 数据进行压缩,压缩率达 0.78%.
- (2)所采用的损伤指标可由压缩数据有效识别结构损伤位置,表明压缩效果良好.
- (3)所采用的损伤指标进行损伤定位时具有一定的抗噪性,简支梁在 20%噪声、连续梁在 10%高斯白噪声下可识别损伤位置.
- (4)采用深度卷积自编码模型压缩的桥梁监测数据保留了桥梁信息中的关键特征.

参考文献

[1] 林健富,黄建亮,程瀛,等.广州新电视塔结构健康监测应变修正计算的研究[J].动力学与控制学报,2011,9(1):68-74.

LIN J F, HUANG J L, CHENG Y, et al. Study on the modified strain of Guangzhou new TV Tower structural health monitoring [J]. Journal of Dynamics and Control, 2011, 9(1): 68-74. (in Chinese)

[2] 王凌波,王秋玲,朱钊,等.桥梁健康监测技术研究现状及展望[J].中国公路学报,2021,34(12):25-45.

WANG L B, WANG Q L, ZHU Z, et al. Current status and prospects of research on bridge health monitoring technology [J]. China Journal of Highway and Transport, 2021, 34(12): 25-45. (in Chinese)

[3] 苏潇阳,康厚军,丛云跃.混合体系多塔斜拉桥竖向刚度评估动力学理论[J].动力学与控制学报,2020,18(4):26-32.

SU X Y, KANG H J, CONG Y Y. Dynamic theory for evaluation on vertical bending stiffness of multi-tower cable-stayed bridge with hybrid system [J]. Journal of Dynamics and Control, 2020, 18(4): 26-32. (in Chinese)

[4] YANG X C, LI H, YU Y T, et al. Automatic pix-

- el-level crack detection and measurement using fully convolutional network [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2018, 33(12): 1090—1109.
- [5] CAI G W, MAHADEVAN S. Big data analytics in online structural health monitoring [J]. *International Journal of Prognostics and Health Management*, 2016, 7(4): 1—12.
- [6] BARBOSH M, SADHU A, VOGRIG M. Multi-sensor-based hybrid empirical mode decomposition method towards system identification of structures [J]. *Structural Control and Health Monitoring*, 2018, 25(5): e2147.
- [7] SONY S, LAVENTURE S, SADHU A. A literature review of next-generation smart sensing technology in structural health monitoring [J]. *Structural Control and Health Monitoring*, 2019, 26(3): e2321.
- [8] BAO Y Q, BECK J L, LI H. Compressive sampling for accelerometer signals in structural health monitoring [J]. *Structural Health Monitoring*, 2011, 10(3): 235—246.
- [9] DUAN Z D, KANG J. Compressed sensing techniques for arbitrary frequency-sparse signals in structural health monitoring [C]//*Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2014*. Bellingham, DC, USA: SPIE, 2014: 90612W.
- [10] BAO Y Q, CHEN Z C, WEI S Y, et al. The state of the art of data science and engineering in structural health monitoring [J]. *Engineering*, 2019, 5(2): 234—242.
- [11] 吴贤国, 邓婷婷, 陈彬, 等. 面向运营隧道结构健康监测系统大数据压缩感知研究[J]. *隧道建设(中英文)*, 2021, 41(4): 674—683.
- WU X G, DENG T T, CHEN B, et al. Research on compressed sensing of big data for structural health monitoring system of operating tunnel [J]. *Tunnel Construction*, 2021, 41(4): 674—683. (in Chinese)
- [12] 张笑华, 肖兴勇, 方圣恩. 面向桥梁结构健康监测的压缩感知动力响应信号重构[J]. *振动工程学报*, 2022, 35(3): 699—706.
- ZHANG X H, XIAO X Y, FANG S E. Dynamic response reconstruction for bridge structural health monitoring based on compressed sensing [J]. *Journal of Vibration Engineering*, 2022, 35(3): 699—706. (in Chinese)
- [13] BAO Y Q, TANG Z Y, LI H. Compressive-sensing data reconstruction for structural health monitoring: a machine-learning approach [J]. *Structural Health Monitoring*, 2020, 19(1): 293—304.
- [14] ALMASRI N, SADHU A, RAY CHAUDHURI S. Toward compressed sensing of structural monitoring data using discrete cosine transform [J]. *Journal of Computing in Civil Engineering*, 2020, 34: 04019041.
- [15] KULLAA J. Damage detection and localization under variable environmental conditions using compressed and reconstructed Bayesian virtual sensor data [J]. *Sensors*, 2021, 22(1): 306.
- [16] 鲍跃全, 李惠. 人工智能时代的土木工程[J]. *土木工程学报*, 2019, 52(5): 1—11.
- BAO Y Q, LI H. Artificial intelligence for civil engineering [J]. *China Civil Engineering Journal*, 2019, 52(5): 1—11. (in Chinese)
- [17] CATBAS N, AVCI O. A review of latest trends in bridge health monitoring [J]. *Proceedings of the Institution of Civil Engineers-Bridge Engineering*, 2023, 176(2): 76—91.
- [18] 倪富陶. 基于深度学习的结构外观病害检测与监测数据挖掘[D]. 东南大学, 2021.
- NI F T. Deep learning based structural surface damage detection and monitoring data mining [D]. Southeast University, 2021. (in Chinese)
- [19] 谭超英. 深度学习法在桥梁健康诊断中的应用研究[D]. 重庆: 重庆交通大学, 2017.
- TAN C Y. Application of Deep learning in bridge health diagnosis [D]. Chongqing: Chongqing Jiaotong University, 2017. (in Chinese)
- [20] 邵红艳, 梁李源, 高士武. 基于卷积自编码神经网络的损伤识别[J]. *科学技术创新*, 2021(11): 140—141.
- SHAO H Y, LIANG L Y, GAO S W. Damage recognition based on convolutional autoencoder neural network [J]. *Scientific and Technological Innovation*, 2021(11): 140—141. (in Chinese)
- [21] SARWAR M Z, CANTERO D. Deep autoencoder architecture for bridge damage assessment using responses from several vehicles [J]. *Engineering Structures*, 2021, 246: 113064.
- [22] 王宇鑫. 基于自编码神经网络的桥梁结构损伤检测研究[D]. 广州: 暨南大学, 2018.
- WANG Y X. Damage detection of bridge structure based on autoencoder [D]. Guangzhou: Jinan University, 2018. (in Chinese)